

LSG : 모델 기반 3차원 물체 인식을 위한 정형화된 국부적인 특징 구조

이 준호[†]

요약

본 연구에서는 모델 기반 3차원 물체인식을 위하여 다양한 물체에 대하여 사용 가능한 일반적이며 정형화된 물체의 국부적인 특징인 LSG(Local Surface Group)를 제안하였다. LSG는 하나의 면과 그 면을 중심으로 바로 이웃하고 있고 주어진 시점에서 동시에 보여지는 면들의 집합이다. 즉, LSG는 시점에 의존하는(viewpoint dependent) 물체의 국부적인 특징이며 그 안에 속성들에 대한 슬롯들을 갖는 구조를 갖는 특징이다. 또한, 어떤 LSG가 물체들을 가장 잘 구별해 낼 수 있는 물체의 특징인가를 결정하는 척도를 Bayesian 확률이론을 이용하여 계산하는 방법을 제시하였다. 20개의 3차원 물체로 구성된 물체 데이터베이스에 대해 실험하였으며 제안된 물체의 특징인 LSG와 Bayesian 확률이론 계산 방법이 신속한 물체 인식을 위해 사용될 수 있다는 점을 보였다.

LSG(Local Surface Group) : A Generalized Local Feature Structure for Model-Based 3D Object Recognition

Juneho Yi[†]

ABSTRACT

This research proposes a generalized local feature structure named "LSG (Local Surface Group) for model-based 3D object recognition". An LSG consists of a surface and its immediately adjacent surfaces that are simultaneously visible for a given viewpoint. That is, LSG is not a simple feature but a viewpoint-dependent feature structure that contains several attributes such as surface type, color, area, radius, and simultaneously adjacent surfaces. In addition, we have developed a new method based on Bayesian theory that computes a measure of how distinct an LSG is compared to other LSGs for the purpose of object recognition. We have experimented the proposed methods on an object database composed of twenty 3D objects. The experimental results show that LSG and the Bayesian computing method can be successfully employed to achieve rapid 3D object recognition.

키워드 : 물체인식(object recognition), 특징(feature), 베이시안 확률(Bayesian theory)

1. 서론

모델 기반 물체인식(model-based object recognition) 시스템[1-7, 10, 12-14]의 설계에 있어서 처음에 결정하여야 할 가장 중요한 문제는 물체인식을 위하여 사용할 물체 특징의 선택이다. 물체들을 가장 잘 구별지을 수 있는 물체들의 두드러진 특징을 물체인식을 위해 이용하는 것이 최대의 인식율을 보장하리라는 것은 명확한 사실이다. 따라서 인식 대상이 되는 물체들을 가장 잘 구별할 수 있는 물체의 특징들을 미리 자동으로 선택할 수 있다면 물체 인식 연구의 가장 중요한 문제가 해결된다고 할 수 있다. 대개의 물체인

식 시스템에서 사용되는 방법은 인식 대상이 되는 물체들을 인지한 상태에서 사람의 판단에 의해 물체인식을 위한 물체의 특징을 결정하는 방법이 사용되어 왔다. 최근에 물체인식을 위해 사용할 물체의 특징을 자동으로 선택하여 줄 수 있는 연구에 대한 보고[8]도 있으나, 물체들을 구별하기 위해 일반적으로 우리가 생각할 수 있는 특징들을 나열하고 그 중 인식 대상이 되는 물체들에 포함된 특징들만을 선택하여 물체인식 시스템을 구현한다는 점에서 다양한 모든 물체에 대하여 적용할 수 있는 일반적인 방법은 아니다. 따라서 인식 대상 물체들이 다양하게 변화할 때도 물체인식을 위해 사용할 수 있도록 정형화된 어떤 특징 구조를 정의하여 사용할 수 있다면 물체인식 시스템의 구현이 매우 용이할 것이다.

본 논문에서는 레인지 영상을 이용한 3차원 물체인식을

* 본 연구는 정보통신연구진흥원 대학기초연구(과제번호 2000-0714-000) 지원으로 수행되었음.

† 종신회원: 성균관대학교 전기전자컴퓨터공학부 교수
논문접수: 2000년 3월 7일, 심사완료: 2001년 9월 20일

위해 다양한 모든 물체에 적용이 가능한 물체의 특징으로서 LSG(Local Surface Group)를 제안한다. LSG는 하나의 면과 그 면을 중심으로 바로 이웃하고 있고 주어진 시점에서 동시에 보여지는 면들의 집합이다. 면들 자체, 면과 면 사이의 관계 등의 여러 속성들을 포괄적으로 정의하여 필요에 따라 속성들을 부가하여 확장시킬 수 있는 구조를 갖는 물체의 국부적인 특징이다. 하나의 물체는 여러 다른 종류의 면(예를 들어, 평면, 구면, 실린더면 등)으로 이루어져 있으므로 하나의 물체는 여러 다른 종류의 LSG를 가지며, 물체에 따라서도 다른 종류의 LSG들을 갖게 된다. 본 연구에서는 인식대상 물체들이 주어지면 컴퓨터 그래픽 기술을 이용하여 LSG를 모두 찾아내고 어떤 LSG가 물체들을 가장 잘 구별해 낼수 있는 물체의 두드러진 특징인가를 Bayesian 확률이론을 이용하여 도출하는 방법을 제시한다. 또한 계산된 결과가 신속하고 효율적인 물체인식을 위하여 어떻게 이용할 수 있는지에 대하여 기술한다.

본 논문의 주요한 의의는 다음과 같다. 첫째, 모델 기반 3차원 물체인식을 위하여 다양한 물체에 대하여 사용 가능한 일반적이며 정형화된 물체의 특징인 LSG를 제안하였다. 둘째, 인식 대상이 되는 물체들이 갖는 LSG들을 컴퓨터그래픽 기술을 이용하여 계산하는 방법을 제시하였다. 셋째, 어떤 LSG가 물체들을 가장 잘 구별해 낼 수 있는 물체의 특징인가를 Bayesian 확률이론을 이용하여 계산하여 물체인식 속도의 향상을 위해 사용될 수 있다는 점을 보였다.

본 논문의 구성은 다음과 같다. 제 2절에서는 3차원 물체인식을 위하여 제안한 물체의 일반 특징인 LSG를 정의한다. 제 3절에서는 off-line으로 인식 대상이 되는 물체들이 가질 수 있는 모든 LSG를 계산하는 것과 함께 인식 대상이 되는 물체들에 대하여 어떤 LSG가 물체 인식을 위해 뚜렷이 구별되는 특징인지를 나타내는 척도를 계산하는 방법을 Bayesian 확률이론을 이용하여 기술한다. 제 4절에서는 본 논문에서 제안된 방법이 신속하고 효율적인 물체인식을 위하여 어떻게 적용될 수 있는지에 대하여 예를 들어 설명한다.

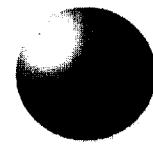
2. LSG(Local Surface Group)

모델 기반 물체인식을 위해 사용할 물체의 특징으로서 우선 생각할 수 있는 간단한 특징으로는 스텝 에지, 루프 에지등에 의해 영역화될 수 있는 면이다. 예를 들어, (그림 1) (a)에서와 같이 에지들에 의해 분리되는 하나의 면을 물체인식을 위한 특징으로 사용하는 경우 (그림 1) (b)의 단순한 두 물체의 인식은 쉽게 이루어 질 수 있다. 하나의 면은 그 면이 어느 물체에 속한 면인지의 정보, 면의 형태, 면적, 면의 색 등의 속성을 가지고 정의하면, (그림 1)의 경우 인식대상 물체는 구와 4면체로서 에지에 의해 영역화

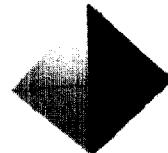
되는 물체의 면의 형태가 평면인지 구면인지만을 판단하면 될 것이다. 하지만 (그림 2)와 같이 여러 종류의 면을 갖는 좀 더 복잡한 물체들이 인식 대상일 경우, 또한 인식 대상 물체의 개수가 많아지면 (그림 1) (a)의 특징은 물체 인식을 위해 효율적이지 못하다.

```
{surface-label : ?
  <model : ?>
  <surface-type : ?>
  <area : ?>
  <radius : ?>
  <color : ?>
}
```

)



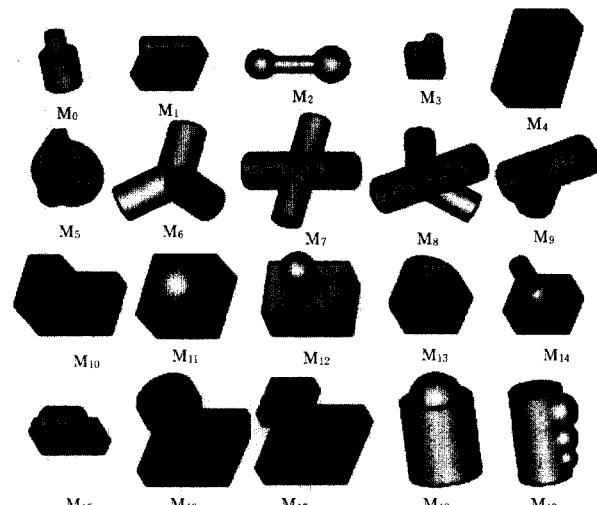
sphere(구)



tetrahedron(4면체)

(a) 물체 인식을 위한 물체의 특징 (b) 인식 대상 물체

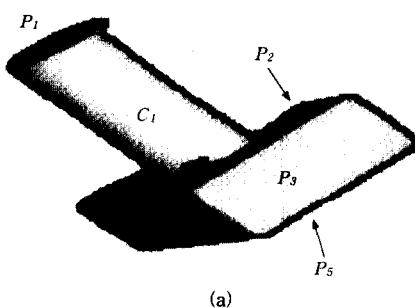
(그림 1) 두 개의 간단한 기하학적 물체를 구별하기 위한 물체 특징의 예



(그림 2) 모델 데이터베이스

본 논문에서는 LSG를 물체인식을 위한 물체의 특징으로 제안한다. LSG는 단순한 특징이라기보다는 여러 가지 확장 가능한 속성들을 솔롯 값으로 갖는, 구조를 갖는 특징이다. LSG는 하나의 면('seed면'이라 명명함)과 주어진 시점(view-point)에서 함께 보이며 이웃하고 있는 면들의 집합이다. (그림 3)에는 면 C_1 을 seed면으로 하고 C_1 과 바로 이웃하면서 주어진 시점에서 함께 보이는 면들인 P_1 과 P_2 로 이루어진 LSG의 한 예를 보여주고 있다. LSG는 하나의 면(seed면)과 바로 이웃하면서 주어진 시점에서 함께 보이는 면들의 집합이므로 어떤 시점에서 한 물체를 볼 때 LSG의 수는 이론적으로 주어진 시점에서 보여지는 면들의 수임을 알 수 있다. 예를 들어, (그림 3)에 보여지는 물체의 경우 주어진 시점에 대해 다섯 개의 LSG가 구해진다. 각 LSG를 [seed면, 이웃면(들)]의 형태로 간략히 기술하면 다섯 개의 LSG는 $[P_1 - C_1], [C_1 - P_1 P_2], [P_2 - C_1 P_3 P_4], [P_4 - P_2 P_3], [P_3 - P_2 P_4]$ 이다. LSG에서 사용되는 면의 형태는 quadric

면으로서 평면형(planar), 불록실린더형(ridge), 오목실린더형(valley), 불록구면형(peak), 오목구면형(pit)이다. (그림 3) (b)에서 보여주는 LSG의 한 예를 통하여 LSG의 구조를 살펴보면 다음과 같다. 처음 3개의 슬롯은 seed면의 이름이 C_1 이고, 이 면의 형태는 밖으로 불록한 실린더면의 형태이며 실린더면의 반지름은 0.75임을 각각 보여준다. LSG의 네 번째 슬롯인 <simultaneously-visible-adjacent-surface s : list of surfaces>에는 seed 면과 함께 보이며 바로 이웃한 면들의 이름(혹은 번호)과 면의 종류, 면적, 반지름(면의 종류가 실린더나 구형일 경우), 그리고 seed 면과 이루는 각도 등이 함께 나타난다. seed 면과 이웃한 면이 이루는 각도는 두 면의 형태가 평면형이거나 실린더형일 때만 적용되며 각 면의 방향의 차이로부터 구한다. 면의 방향은 평면형일 경우 면의 법선 벡터 방향으로, 실린더형일 경우 실린더 축의 방향으로 정의한다. 다른 종류의 면들 사이의 각도는 정의되지 않으므로 NIL로 표시한다.



(a)

(b) An example of LSG(Local Surface Group)

```
{seed-surface-label : C1
<model-label : ***>
<surface-type : ridge(1)>
<radius : 0.75>
<simultaneously-visible-adjacent-surfaces : [
  (P1, planar(0), area, radius(nil), 00)
  (P2, planar(0), area, radius(nil), 00)]>
}
```

(c) Simplified LSG

```
{surface-type-of-seed-surface : ridge(1)
  surface-type-of-
    <simultaneously-visible-
      adjacent-surfaces : (planar(0), planar(0))>
    <sum-of-angle : 00>
}
```

(그림 3) LSG의 한 예

우리가 주위에서 접하는 모든 물체들은 스텝에거나 루프에지에 의해 영역화되는 여러 형태의 면들로 구성되어 있으며 여러 다양한 슬롯 값들을 갖는 다른 종류의 LSG들을 갖고 있다. LSG는 면의 색상이나 질감과 같은 다른 속성들도 포함하기 위해 슬롯의 개수를 확장할 수도 있다. 또한 LSG는 하나의 면(seed면)과 바로 이웃한 면들만의 집합이므로 물체의 국부적인 특징이다. 입력 레인지 영상에서 인식 대상 물체가 다른 물체에 의해 완전히 가려져 있지 않

다면 최소한 하나 또는 그 이상의 LSG가 온전하게 검출될 것이므로 검출되는 LSG들로부터 여전히 옳은 인식 결과를 주는 물체에 대한 가설이 생성될 것이다. 다시 한번 상기하면 LSG는 시점에 의존하는(viewpoint dependent) 물체의 국부적인 특징이며 그 안에 속성들에 대한 슬롯들을 갖는 구조를 갖는 특징이다. LSG는 인식 대상 물체들이 바뀌어도 3차원 물체 인식을 위한 정형화된 특징으로 사용할 수 있다는 점에서 효율적이다.

3. LSG의 차별성(saliency) 척도 계산

여기서는 인식 대상이 되는 물체들이 주어질 때 어떤 LSG가 물체들을 가장 효과적으로 구별짓는 두드러진 특징인가의 척도를 '차별성척도'라고 정의하고 이 차별성척도를 계산하는 방법을 기술한다. LSG의 차별성척도를 Bayesian 이론의 *a posteriori* 확률로 도출하기 위하여 결합 확률(joint probability)인 $P(m_k, M_i, viewpoint_i, viewpoint_j, k = 1, \dots, f, i = 1, \dots, N \text{ and } j = 1, \dots, v)$ 로부터 출발한다. m_k , M_i , 그리고 $viewpoint_i$ 는 각각 사용하는 물체의 특징, i 번째 모델 물체, 그리고 선택된 시점들의 집합 중 j 번째 시점을 나타낸다. f , N , v 는 각각 물체의 특징, 인식대상 물체, 시점들의 개수를 표시한다. 이 결합 확률에는 인식 대상 물체들에 대한 각 특징이 갖는 정보가 함축되어 있다.

3.1 사용되는 기호들의 정의

$P(m_k, M_i, viewpoint_i)$: joint probability of m_k (사용하는 물체의 특징), M_i (i 번째 물체), $viewpoint_i$ (시점들의 집합 중 j 번째 시점). $k = 1, \dots, f$, $i = 1, \dots, N$, $j = 1, \dots, v$.

$P(M_i)$: 주어진 물체가 M_i 일 확률을 나타내는 *a priori* 확률, 즉, $\sum_{i=1}^N P(M_i) = 1.0$.

$P(m_k/M_i)$: likelihood를 나타내는 조건부 확률로서 [$P(m_k/M_i) > P(m_k/M_j)$]로 나타내어지는 부등식은 물체의 특징, m_k 가 물체 M_i 의 특징일 가능성이 물체 M_j 의 특징일 가능성보다 큼을 나타낸다.

$P(M_i/m_k)$: 입력 영상에서 물체의 특징, m_k 가 검출될 때 물체 M_i 가 입력 영상에 존재할 확률을 나타내는 *a posteriori* 확률.

정의 : $P(M_i/m_k)$ 를 물체의 특징, m_k 의 물체 M_i 에 대한 차별성 척도로 정의한다.

위에 정의한 차별성 척도를 예를 들어 설명하면 다음과 같다. m_k 의 모델 물체 M_i 에 대한 차별성 척도가 1.0이면

(즉, $P(M_i/m_k) = 1.0$ 이면), 물체의 특징 m_k 는 물체 M_i 만이 갖고 있는 특징이다. 다시 말하면 입력 영상에서 물체의 특징, m_k 가 검출되면 물체 M_i 가 입력 영상에 확실히 존재함을 알려준다. 한편, 입력 영상에서 물체의 특징, m_2 가 검출되고 off-line으로 미리 계산된 $P(M_i/m_2)$ 가 $P(M_3/m_2) = 0.425 > P(M_0/m_2) = 0.401 > P(M_5/m_2) = 0.174$ 라면 검출된 물체의 특징, m_2 에 대해 입력 영상에, M_3, M_0 그리고 M_5 의 순서로 물체가 존재할 확률이 높음을 보여준다

3.2 $P(M_i/m_k)$ 의 계산 방법

Bayesian 확률 이론에 의해 도출되는 *a posteriori* 확률인 $P(M_i/m_k)$ 를 물체 인식을 위해 이용하는 것은 이론적으로 많은 연구가 되어 왔으나 계산 방법의 어려움으로 인하여 실제 사용된 경우는 드물다. 여기서는 컴퓨터그래픽기술과 컴퓨터 비전을 이용하여 $P(M_i/m_k)$ 를 계산하는 방법에 대하여 기술한다. 다음에서는 위에서 정의된 것들의 계산치를 기호의 위에 $\hat{P}(\cdot)$ 을 붙여 나타내기로 한다. $\hat{P}(M_i)$ 는 입력 영상에 물체 M_i 가 나타나는 빈도를 관찰하여 그 빈도를 모든 물체들의 관찰 빈도수로 나눔으로써 구할 수 있다. 예를 들어 공장 환경에서 컨베이 벨트에 어떤 완성 제품을 이루는 여러 가지 부품들이 흘러가고 있을 때 경험적으로 어떤 부품이 다른 부품에 비해 얼마나 자주 나타나는지 작업자의 관찰에 의해 알 수 있다. 일단 물체인식을 위하여 사용할 물체의 특징을 결정하면 $\hat{P}(m_k, viewpoint_j/M_i)$ 는 j 번째 시점(*viewpoint_j*)에서 M_i 를 볼 때 과연 물체의 특징, m_k 가 몇 번이나 관찰되는 지의 빈도수로 계산할 수 있다.

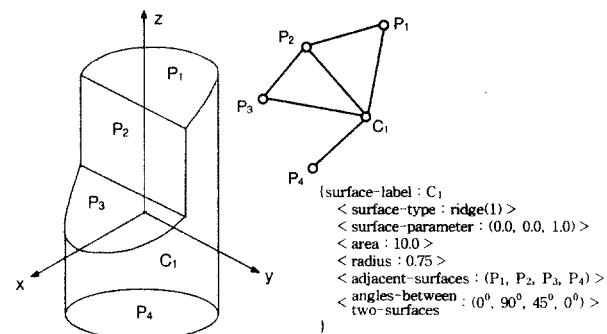
$$\hat{P}(m_k, viewpoint_j/M_i) = \frac{\# \text{occurrences of the feature } m_k \text{ in } M_i \text{ for } viewpoint_j}{\# \text{occurrences of all features } m_l, l=1, \dots, m \text{ in } M_i \text{ for all viewpoints}} \quad (1)$$

우리가 구하고자 하는 $\hat{P}(M_i/m_k)$ 는 Bayesian 법칙을 이용하여 식 (2), 식 (3)과 같이 구한다.

$$\hat{P}(m_k/M_i) = \sum_{j=1}^v \hat{P}(m_k, viewpoint_j/M_i) \quad (2)$$

$$\frac{\hat{P}(M_i/m_k)}{\sum_{i=1}^N \hat{P}(M_i) \sum_{j=1}^v \hat{P}(m_k, viewpoint_j/M_i)} \quad (3)$$

식 (2)로부터 물체 M_i 에 물체의 특징, m_k 가 존재하지 않는다면 $\hat{P}(m_k/M_i) = 0.0$ 가 되어 식 (3)의 $\hat{P}(M_i/m_k) = 0.0$ 이 됨을 알 수 있다. 인식 대상 3차원 물체들이 컴퓨터상에 서 (그림 4)와 같은 방법으로 저장되어 있다고 가정하자.



(a) model object

(b) attribute-relational graph

(그림 4) 속성 상관 그래프 표현 방법 (a) 모델 물체 (b) 원편 물체의 속성 그래프와 C_1 노드가 갖는 속성들의 집합

한 물체에 대하여 LSG를 추출하는 방법은 다음과 같다. 해당 물체를 각 시점에 대해 z-buffer 알고리듬[9]을 이용하여 면의 라벨(즉, 번호)과 함께 렌더링하고 렌더링된 영상을 스캔(scan)하면서 영상처리 알고리듬들을 적용하여 LSG를 추출하게 된다. 스텝, 루프, 에지 검출, 콤파넌트 레이블링, 면의 형태 정보 추출, 면의 방향 계산 등을 위해 표준적으로 사용되는 영상처리 알고리듬들을 사용하였다. 모델 물체의 렌더링을 위해 구 표면상에 대체로 균일하게 분포된 162개의 시점을 사용했는데 이 시점들은 정20면체를 구에 투영한 다음 더 세분해서 얻어지는 다면체들을 이용하여 구하였다[10, 11]. 단위 구상의 한 시점이 (그림 5)와 같이 나타낼 수 있다. (그림 5)에서 보여지듯이 하나의 시점 (θ, ϕ) 의 방향에서 물체를 보았을 때 나타나는 LSG들을 구하고, 이를 162개의 시점에 대하여 반복 수행하면 한 물체에 대한 LSG들을 모두 계산하게 된다. LSG를 계산하는 개략적인 전체 과정은 다음과 같이 요약된다.

for $i = 1, 2, \dots, N$ (N 개의 인식대상 물체에 대하여)

 for $j = 1, 2, \dots, v$ (v 개의 시점에 대하여)

 Render the range image of the object, M_i , for

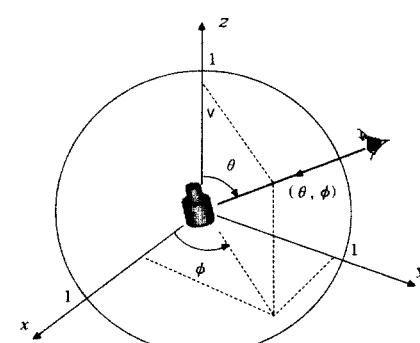
viewpoint_j, along with surface labels.

 Scan the range image and collect LSGs.

 end for j

end for i

Compute $\hat{P}(M_i/m_k)$'s and return the indexing table.

(그림 5) 단위 구상의 하나의 시점, (θ, ϕ)

4. 실험

제3절에서 계산되는 ‘차별성척도’의 적용 방법을 간략히 기술하면 다음과 같다. 입력 영상에서 LSG들을 검출하고 검출된 각 LSG에 대해 해당 LSG를 포함하고 있을 확률이 가장 높은 몇 개의 후보 물체들을 선택하기 위하여 ‘차별성척도’ 값을 이용하게 된다. 본 연구에서는 (그림 3) (c)의 단순화한 LSG(simplified LSG)에 대하여 차별성척도를 계산한 결과를 보이기로 한다(이하에서는 단순화한 LSG를 SLSG라 칭하기로 한다). LSG의 전체 정의를 사용하여 차별성척도를 구하는 경우 약간 다른 슬롯 값들에 대하여도 다른 종류의 LSG가 과다하게 만들어지고 입력 영상에서 검출된 LSG에 부합되는 후보 물체를 찾는 계산량도 많아지기 때문이다. SLSG는 LSG의 부분 집합으로 간략화한 경우이고 SLSG에서는 이웃하고 있는 면들의 각각을 구별하지 않고 그들의 면의 형태 정보와 seed 면과 이루는 각도들의 합을 사용하였다. SLSG는 차별성척도를 계산한 결과를 보이기 위한 하나의 예이며 입력 영상에서 SLSG를 검출하여 검출된 SLSG와 가장 잘 부합되는 후보 물체를 구하고 LSG의 상세한 슬롯 값들을 이용하여 물체에 대한 가설을 검증하는 방식을 취하면 된다.

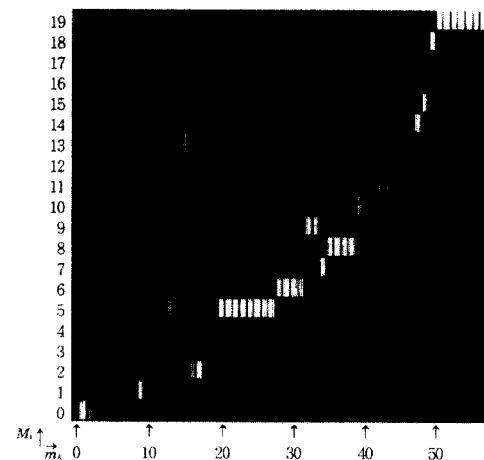
계산 속도를 분석하면 모델 데이터베이스의 각 물체를 162개의 시점에 대해 렌더링을 하는 부분이 전체 시간을 지배하며 시간복잡도(time complexity)는 $O(n^2)$ 이다. 여기서 n^2 는 가로, 세로의 길이가 각 n 픽셀개를 갖는 z-buffer의 크기이다. (그림 2)의 20개 물체들로 이루어진 데이터베이스에 대해 계산한 $\hat{P}(M_i/m_k)$ 의 분포를 (그림 6)에 가시화하였다. m_k 는 SLSG를 나타내며 (그림 6)의 가로축은 주어진 20개의 물체에 대해 57개의 다른 SLSG(즉, $m_0 \dots m_{56}$)들이 구해졌음을 보여준다. 세로축은 20개의 물체들을 나타낸다. 검정색 영역은 $\hat{P}(M_i/m_k) = 0.0$, 흰색 영역은 $\hat{P}(M_i/m_k) = 1.0$, 밝은 그레이 값일수록 $\hat{P}(M_i/m_k)$ 의 값이 1.0에 가까움을 나타낸다. (그림 6)은 다음과 같은 중요한 정보를 보여준다. 물체의 특징 m_k 의 물체 M_i 에 대한 분별력이 1.0이면 (즉, $\hat{P}(M_i/m_k) = 1.0$ 이면), 물체의 특징 m_k 는 모델 물체 M_i 만이 갖고 있는 특징이다. 다시 말하면, 입력 영상에서 물체의 특징 m_k 가 검출되면 모델 물체 M_i 가 입력 영상에 확실히 존재함을 알려준다. 한편, 입력 영상에서 물체의 특징 m_k 가 검출되면, ($\hat{P}(M_3/m_2) = 0.425 > \hat{P}(M_0/m_2) = 0.401 > \hat{P}(M_5/m_2) = 0.174$)의 결과로부터 검출된 물체의 특징 m_k 에 대해 입력 영상에 M_3 , M_0 그리고 M_5 의 순서로 물체가 존재할 확률이 높음을 보여준다. 그러므로 검출된 물체의 특징 m_k 에 대해 물체 M_i 의 가설을 먼저 고려한 다음 가설의 검증이 실패할 경우 M_0 , M_5 에 대한 가설의 순

서로 겹중하게 되면 영상에서 검출된 특징에 가장 잘 부합하는 물체들만을 잘 부합되는 순서로 검증함으로써 인식 속도를 획기적으로 단축시킬 수 있다. 앞에서도 기술하였듯이 검증 과정은 LSG의 각 슬롯 값들과 컴퓨터에 저장된 물체의 속성 상관 그래프의 상세한 비교로 이루어 질 수 있다.

LSG의 전체 및 부분 정의를 사용하여 수행하게 되는 물체인식의 효율성을 보이기 위한 실험을 행하였다. M_0, M_3, M_5, M_{15} 물체들을 실제 제작하여 얻은 (그림 3) (a) 영상을 포함하여 13개의 실제 레인지 영상에 대하여 실험한 결과와 (그림 2)의 각 물체에 대하여 10개의 임의 시점에서 보이는 영상을 생성하여 만든 총 200개의 합성영상에 대하여 실험한 결과를 <표 1>에 정리하였다. 합성 영상의 경우 89%의 인식율을, 실제 영상의 경우 84.6%의 인식율을 보였으며 두 경우 모두 $\hat{P}(M_i/m_k)$ 값의 순서로 3번째 안에 드는 가설로서 올바른 인식 결과를 얻을 수 있었다. 제안된 LSG의 구조를 이용하여 다른 속성의 슬롯을 확장한 특징을 사용하면 좀 더 나은 인식율을 기대할 수 있으리라고 사료된다.

<표 1> 물체 인식 결과

실험영상	인식율	올바른 인식결과를 생성한 가설의 위치
200개의 합성영상	89.0% (178/200)	2.80
13개의 실제 영상	84.6% (11/13)	2.68



(그림 6) (그림 2)에서 보여준 20개 물체들로 이루어진 모델 데이터베이스에 대한 $P(M_i/m_k)$ 의 분포 : 검정 영역은 $P(M_i/m_k) = 0.0$, 흰색 영역은 $P(M_i/m_k) = 1.0$, 밝은 그레이 값일수록 $P(M_i/m_k)$ 의 값이 1.0에 가까움을 나타낸다.

5. 결론

본 연구에서는 모델 기반 3차원 물체인식을 위하여 다양한 물체에 대하여 사용 가능한 일반적이며 정형화된 물체

의 국부적인 특징인 LSG를 제안하였다. 인식 대상이 되는 물체들이 갖는 LSG들을 컴퓨터그래픽 기술을 이용하여 계산하는 방법을 제시하였고 어떤 LSG가 물체들을 가장 잘 구별해 낼 수 있는 물체의 특징인가를 Bayesian 확률이론을 이용하여 계산하였다. Bayesian 확률이론을 이용하여 도출되는 *a posteriori* 확률을 물체 인식에 적용하는 것은 이론적으로 많은 연구가 되어 왔으나 계산 방법의 어려움으로 인하여 실제 사용된 경우는 드물었으나 본 연구에서 제안한 방법으로 실제 계산이 가능하며 획기적인 물체 인식 속도의 향상을 위해 사용될 수 있다는 점을 보였다.

참 고 문 헌

- [1] M. Wheeler and K. Ikeuchi, "Sensor modeling, probabilistic hypothesis generation, and robust localization for object recognition," IEEE Transactions on Pattern Analysis and Machine Intelligence, 17(3) : pp.252-265, March, 1995.
- [2] Jeffrey Beis and David Lowe, "Learning indexing functions for 3-D model-based object recognition," In AAAI Workshop, April, 1993.
- [3] Andrea Califano and Rakesh Mohan, "Multidimensional indexing for recognizing visual shapes," IEEE Transactions on Pattern Analysis and Machine Intelligence, April, 1994.
- [4] I. Rigoutsos and R. Hummel, "Distributed Bayesian object recognition," In Proc. IEEE Conf. on Computer Vision and Pattern Recognition, June, 1993.
- [5] F. Stein and G. Medioni, "Structural indexing : Efficient 2-D object recognition," IEEE Transactions on Pattern Analysis and Machine Intelligence, 14(12) : pp.1198-1204, December, 1992.
- [6] F. Stein and G. Medioni, "Structural indexing : Efficient 3-D object recognition," IEEE Transactions on Pattern Analysis and Machine Intelligence, 14(2) : pp.125-145, February, 1992.
- [7] P. Flynn and A. K. Jain, "Object recognition using invariant feature indexing of interpretation tables," CVGIP : Image Understanding, March, 1992.
- [8] K. Ikeuchi and T. Kanade, "Automatic generation of object recognition programs," Proceedings of IEEE, 6(8) : pp.1016-1035, August, 1988.
- [9] J. Foley, A. van Dam, S. Feiner, and J. Hughes, 'Computer graphics : principles and practice,' Addison Wesley, 1992.
- [10] C. H. Chen and A. C. Kak, "A robot vision system for recognizing 3-D objects in low-order polynomial time," IEEE Transactions on Systems, Man, and Cybernetics, 19(6) : pp.1535-1563, November/December, 1989.
- [11] Philippe Brou, "Using the Gaussian image to find the orientation of objects," The International Journal of Robotics Research, 3(4) : pp.89-125, 1984.
- [12] W. M. Wells, "Statistical approaches to feature-based object recognition," International Journal of Computer Vision, 21(1) : pp.63-98, 1997.
- [13] C. F. Olson, "Probabilistic indexing for object recognition," IEEE Transactions on Pattern Analysis and Machine Intelligence, 17(5) : pp.518-522, 1995.
- [14] J. S. Beis and D. G. Lowe, "Indexing without invariants in 3D object recognition," IEEE Transactions on Pattern Analysis and Machine Intelligence, 21(10) : 1000-1015, 1999.



이 준 호

e-mail : jhyi@ece.skku.ac.kr

1985년 서울대학교 전기공학과(학사)

1987년 The Pennsylvania State University, Department of Electrical Engineering(석사)

1994년 Purdue University, School of Electrical and Computer Engineering(공학박사)

1994년~1995년 University of California, Riverside 연구원

1995년~1997년 한국과학기술연구원 선임연구원

1997년~2001년 성균관대학교 전기전자컴퓨터공학부 조교수

2001년~현재 성균관대학교 전기전자컴퓨터공학부 부교수

관심분야 : 컴퓨터비전 기반 HCI